




S. Geček, J. Klanjšček, T. Klanjšček, N. Marn



Grupa za ekološko modeliranje u Zavodu za istraživanje mora i okoliša istražuje, stvara i upotrebljava modele u cilju boljeg razumijevanja i upravljanja okolišem. **Empirijski** modeli opisuju korelacije poput temperature i cvjetanja mora, izlaganja toksikantima i ekspresije gena, itd. Takvi modeli zahtijevaju puno podataka, prikladni su ponajviše za promatranje događaja na *sličnim* vremensko-prostornim skalama i mogu nam pomoći predviđati situacije koje smo već iskusili. Kada želimo povezati *različite* vremensko-prostorne skale i predviđati ishode situacija za koje *nemamo* nječenja, potrebni su nam **mehanistički** modeli koji opisuju glavne karakteristike sustava i njihove međuovisnosti. Iako u pravilu zahtijevaju manje podataka od empirijskih modela, zbog izuzetne kompliciranosti sustava u okolišu, mehanistički modeli zahtijevaju detaljno poznavanje procesa i njihove važnosti za problem od interesa.

Počevši od biokemijskog nivoa, stvaramo i upotrebljavamo mehanističke modele koji opisuju rast i razmnožavanje organizama u ovisnosti o karakteristikama okoliša. Razumijevanje rasta i razmnožavanja jedinki pomaže nam modelirati dinamiku divljih i uzgojnih populacija. Razumijevanje dinamike populacija omogućuje nam računanje najboljih strategija gospodarenja tim populacijama (izlov, poboljšanje efikasnosti prehrane), te izradu modela cijelih hranidbenih lanaca i mreža i računanje utjecaja jedne populacije na drugu. Na razini ekosustava, razvijamo modele koji povezuju biološke, geokemijske i fizikalne procese (eutrofikacija, razgradnja organske materije, strujanje, sedimentacija), kao i modele za procjenu utjecaja raznih oblika zagađenja. Razvijeni skup integriranih metoda i modela za simulaciju široke lepeze procesa karakterističnih za jedinku ili čak za složene ekosustave, omogućuje nam računanje kapaciteta okoliša za ljudske aktivnosti na mnogo različitih polja (industrija, ribarstvo, uzgoj, turizam).

Modeli temeljeni na teoriji Dinamičkih Energijskih Budžeta (DEB) opisuju akviziciju i raspodjelu energije kao posljedicu uvjeta u okolišu (dostupnost hrane, temperatura, toksikanti). Njima možemo izračunati rast i razmnožavanje jedinki čak i u okolišima za koje *nemamo* mjerenja. Koristeći DEB modele promatrali smo, na primjer, bioakumulaciju i prijenos perzistentnih lipofilnih toksikana od majke na potomke kod sisavaca (Slika 1), kako izlaganje kadmiju utječe na rast bakterija (Slika2) i kako rast riba u uzgoju ovisi o scenarijima hranjenja i temperaturi mora (Slika 3).

The diagram illustrates the flow of energy and toxicants through a food chain. It shows a mother (Majka) and her offspring (Potomci). Energy (black arrow) flows from food (Hrana) to the mother and then to the offspring. Toxicants (red arrow) flow from food (Hrana) to the mother and then to the offspring via milk or blood (MLIJEKO ili KRV). The mother's box is labeled with 'Rast' (Growth) and 'Energija (metabolizam), Fekalije' (Energy (metabolism), Feces).

Slika 1: Majke sisavaca, uzimajući energiju iz hrane (crno), bioakumuliraju i toksikante (crveno) koje dojenjem prenose sljedećoj generaciji.

Izlaganje Cd(II)

Bioakumulacija Cd(II)

Kreacija ROS (reactive oxygen species)

Fiziološki efekti

Rast bakterija

Gustoća stanica

sati

Povećanje izlaganja

Do 150mM

Slika 2: pomoću mehanističkog modela kadmija (Cd) moguće je predvidjeti rast izlaganja do 150mM/ (crne linije) korist

Slika 2: pomoću mehanističkog modela za toksičnost kadmija (Cd) moguće je predvidjeti rast bakterija za izlaganja do 150mg/l (crne linije) koristeći rast bakterija za 0, 10, i 20 mg/l (crvene linije).

Slika 3: Uvjeti na uzgajalištu: normalizirana hrana i temperatura tokom tri dijela uzgoja.

Akcija	Poboljšanje
35% pov. 1	9%
50% smanji 2	3%
20% smanji 3	2%

Modeli sugeriraju da se povećanjem hranjenja u prvoj trećini uzgojnog ciklusa može značajno poboljšati efikasnost

The diagram illustrates a two-group system with feedback loops. Two blue ovals represent the groups: "Gupa 1 Mlad" (Group 1 Young) and "Grupe 2 Spolno zreli" (Group 2 Sexually mature). The transitions between them are labeled with parameters: a_{11} (self-loop on Group 1), a_{21} (from Group 1 to Group 2), a_{12} (from Group 2 to Group 1), and a_{22} (self-loop on Group 2). Below the diagram, the state-space model is given as:

$$\begin{bmatrix} x_1(t+1) \\ x_2(t+1) \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix}$$

The matrix $\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$ is circled in red in the original image.

Individualni procesi rasta i razmnožavanja
kao funkcija parametara okoliša iz DEB teorije

Slika 4: Matrični model koji predviđa populaciju podijeljenu na grupe (npr. spolno nezrele i spolno zrele individue) u trenutku $t+1$ iz podataka o populaciji u trenutku t koristeći individualni mehanistički model.

Razumijevanje dinamike populacija ključno je za uspješno upravljanje okolišem. Dinamiku populacija istražujemo modelima koji se temelje na rastu i razmnožavanju individua (Individual Based Models), modelima populacija podijeljenih na funkcionalne skupine u kojima su prijelazi među skupinama ovisi o individualnim procesima (npr. matricni modeli na Slici 4), ili modelima koji opisuju osnovne procese na razini populacije (npr. VPA analiza utjecaja izlova na incune u Jadranu, Slika 5). Modeliramo i interakciju populacija (plijen-predator, kompeticija, suradnja), kako bi bolje razumjeli međuovisnosti organizama u okolišu, odredili optimalni izlov riba i sl.

Legend:

- Procjena Santojanni et al.
- Optimalan broj jedinici
- Gornja i donja granica

Godina	Procjena Santojanni et al. (x 10 ³)	Optimalan broj jedinici	Gornja granica (x 10 ³)	Donja granica (x 10 ³)
1975	6.0	9.5	10.5	9.5
1976	12.5	9.5	10.5	9.5
1977	16.5	9.5	10.5	9.5
1978	23.0	9.5	10.5	9.5
1979	21.0	9.5	10.5	9.5
1980	18.0	9.5	10.5	9.5
1981	11.0	9.5	10.5	9.5
1982	7.0	9.5	10.5	9.5
1983	6.5	9.5	10.5	9.5
1984	4.5	9.5	10.5	9.5
1985	3.5	9.5	10.5	9.5
1986	1.5	9.5	10.5	9.5
1987	1.0	9.5	10.5	9.5
1988	2.5	9.5	10.5	9.5
1989	3.5	9.5	10.5	9.5
1990	4.0	9.5	10.5	9.5
1991	4.5	9.5	10.5	9.5
1992	4.0	9.5	10.5	9.5
1993	5.5	9.5	10.5	9.5
1994	6.5	9.5	10.5	9.5
1995	7.0	9.5	10.5	9.5

Slika 5: Procjenjeni broj inćuna u Jadranu u periodu od 1975 do 1996 uspoređen s optimalnim brojem spolno zrelih jedinki koji osiguravaju MSY (max održivi izlov). Od 1982 godine stok inćuna je u ispod svoje optimalne razine, te se može smatrati prelovljenim

Kvantifikacija posljedica ljudskih aktivnosti na okoliš (eutrofikacija i povećanje organske tvari, onečišćenje okoliša polutantima) putem modela zahtijeva povezivanje modela dinamike populacija i modela biogeokemijskih procesa, te poznavanje fizikalnih instanci kao što su dinamika vodenih masa (Slika 6a), vrijeme izmjene vode (Slika 6b) , te dinamika transporta u sediment.

Modeli razgradnje organske tvari stavljaju naglasak na potrošnju kisika (Slika 7) i produkciju kemijskih tvari s potencijalno nepoželjnim posljedicama za ekosustav. Procjenu utjecaja mineraliziranog dušika i fosfora, umjetno uvođenog u ekosustav uzgojem ribe, kanalizacijskim ispuštima i poljoprivredom vršimo pomoću modela rasta fitoplanktona (Slika 8). Modeli opisuju interakciju između uzimanja nutrijenata, kolekcije svjetlosne energije, autotrofnog rasta i predacije od viših trofičkih nivoa.

```

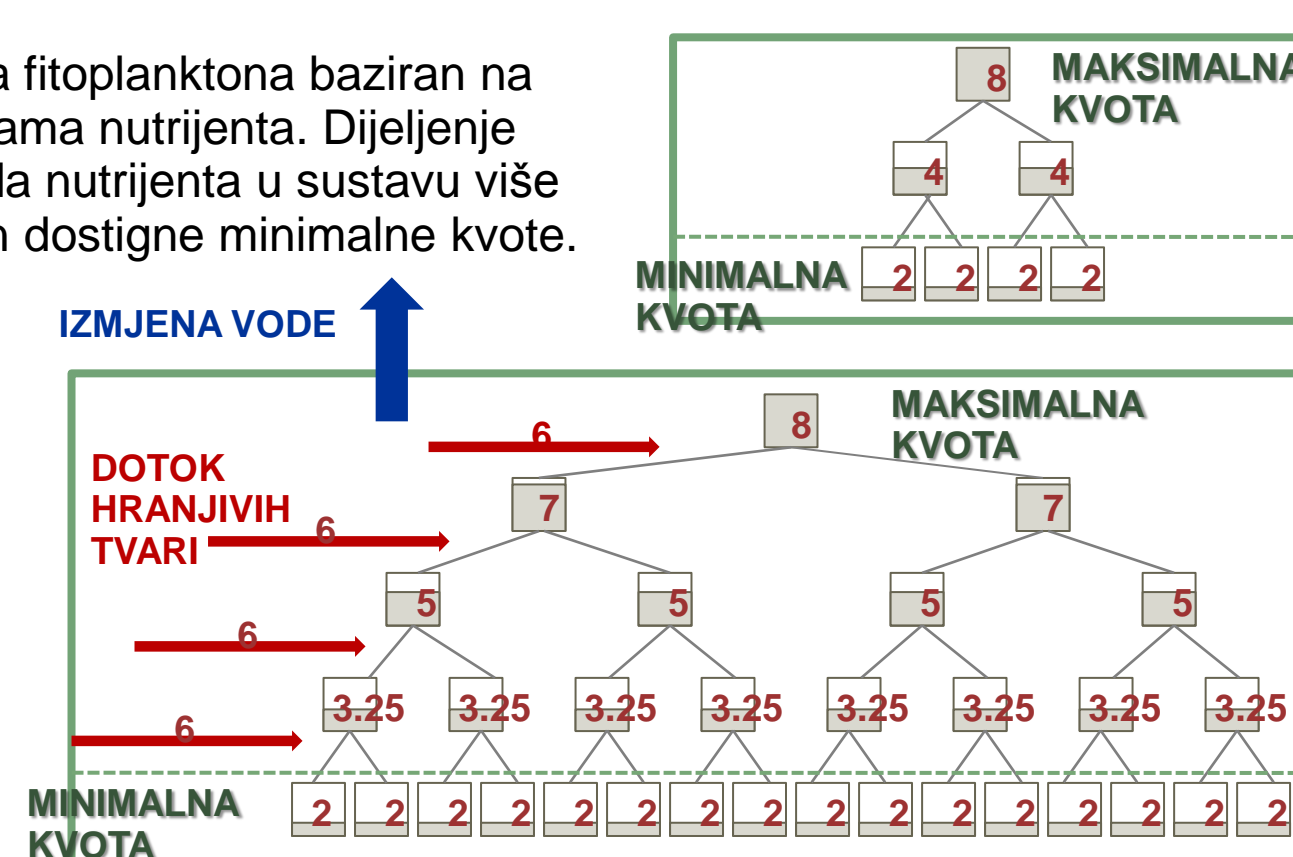
graph TD
    A((Razgradnja nepogledene hrane)) --> F[DINAMIKA KISIKA]
    B((Razgradnja fečesa)) --> F
    C((Izmjena voda-zrak)) --> F
    D((Izmjena zbog hidrodinam procesa)) --> F
    E((Primarna produkcija)) --> F
    G((Disanje riba i fitoplanktona)) --> F
  
```

Model u COD (*Chemical oxygen demand*) jedinicama stehiometrijski određuje količinu potrebnog kisika za razgradnju *organske tvari (feces i nepojedena hrana)* prema njenom sastavu, simulira dinamiku bakterijske razgradnje, te procjenjuje produkciju CO_2 i NH_3 .

Slika 7: Konceptualni prikaz procesa uključenih u model dinamike kisika za područje Bolinao (Filipini) u kojem je smješteno 1170 kaveza za uzgoj riba.

Slika 8: Model rasta fitoplanktona baziran na intracelularnim kvotama nutrijenta. Dijeljenje stanice prestaje kada nutrijenta u sustavu više nema, a fitoplankton dostigne minimalne kvote.

U slučaju kada su povećani **dotoci** **nutrijenata** i smanjenja **izmjena vode**, koncentracija fitoplanktonske biomase rapidno raste.



Slika 6: Dinamika vodene mase u području Bolinao (Filipini) simulirana je pomoću trodimenzionalnog numeričkog modela plimne dinamike baziranog na metodi konačnih elemenata i inkrementalnoj asimilaciji mjerenih strujnih podataka. Dobiveno strujno polje korišteno je u modelima dinamike kisika i fitoplanktona.

(a) Uсредnjena jačina strujnog polja u blizini kaveza i koraljnog grebena (velika slika) i batimetrijski kritično područje za postavljanje kaveza (mala slika).

Poster vrlo šturo prikazuje samo manji dio tema, metoda i rezultata naših istraživanja. Naši modeli su, osim u istraživačke svrhe, primjenjivani i u zakonodavstvu, industriji i očuvanju prirode, ponajviše kroz studije utjecaja na okoliš. Smatramo da su naši pristupi i znanja relevantni za sve koji se bave okolišem, bolestima, rastom ili uzgojem organizama i iskorištavanjem prirodnih resursa.

Mišljenja smo da od svatko tko radi eksperiment ima na umu *nekakav* model sustava kojeg promatra. Preciziranje modela i njegov razvoj može pomoći opisati procese, postaviti eksperimente, kvantificirati zaključke, pomoći usporediti naoko neusporedive sustave, iznaći nove hipoteze i usmjeravanjem eksperimentalnog rada uštedjeti sredstva. Zato vjerujemo da postoji vrlo veliki potencijal za poboljšanje suradnje s ostalom Instituta.

Zahvaljujemo voditelju našeg laboratorija, prof. dr.sc. Tarzanu Legoviću, na godinama nesebičnih napora u cilju našeg znanstvenog napretka, te napretka teorijske ekologije na Institutu i u Hrvatskoj. Zahvaljujemo i našim kolegama iz laboratorija i zavoda, te brojnim financijerima: MZOŠ, UKF, HRZZ, HE Dubrovnik, te partnerima iz privrede.